

## 基于三维UNet与混合焦点损失函数的脑肿瘤全自动分割算法

田恒屹, 肖洪兵, 计亚荣, Rahman Md Mostafizur  
北京工商大学人工智能学院, 北京 100048

**【摘要】**针对脑肿瘤分割方法中由于正常脑组织、脑肿瘤等不同类别的数据量严重不平衡,导致分割精度受到极大影响的问题,提出一种结合混合焦点损失函数与三维UNet(3D UNet)的全自动脑肿瘤分割算法。在3D UNet模型框架中,使用包含焦点损失与改进的焦点Tversky损失的混合损失函数,两种损失函数可以优势互补,分别缓解输入与输出数据类不平衡带来的不利影响,使分割模型聚焦在难以分类和学习的样本上。利用公开的脑肿瘤数据集进行相关实验,提出的混合焦点损失函数分割模型在完整肿瘤区域、核心肿瘤区域(TC)和增强肿瘤区域(ET)的Dice均值分别可达89.01%、88.67%与83.74%,豪斯多夫距离均值分别为14.29、5.01与3.84 mm,实验结果表明,基于混合损失函数的深度学习分割模型可以显著提升由于数据类不平衡导致的难以分类区域(TC和ET)的分割效果。

**【关键词】**脑肿瘤;深度学习;3D UNet;混合焦点损失函数

**【中图分类号】**R318;TP317.4

**【文献标志码】**A

**【文章编号】**1005-202X(2023)09-1114-07

### Fully automatic segmentation algorithm of brain tumor based on three-dimensional UNet and hybrid focal loss function

TIAN Hengyi, XIAO Hongbing, JI Yarong, Rahman Md Mostafizur  
School of Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

**Abstract:** A fully automatic brain tumor segmentation algorithm combining hybrid focus loss function and 3D UNet is proposed to address the problem of low segmentation accuracy caused by the serious data imbalance of different categories such as normal brain tissue and brain tumor. In 3D UNet framework, the hybrid focus loss function including focus loss and improved focus Tversky loss which possess complementary advantages can effectively alleviate the adverse effects caused by the class imbalance of input and output data, and make the segmentation model focus on the samples which are difficult to be classified and learned. The experiments on public brain tumor dataset show that the proposed segmentation model with hybrid focal loss function can achieve a mean Dice coefficient of 89.01%, 88.67%, and 83.74% in whole tumor, tumor core and enhanced tumor, respectively, and that the mean Hausdorff distances were 14.29, 5.01 and 3.84 mm, respectively. The segmentation model based on hybrid focal loss function can significantly improve the segmentation accuracy of tumor core and enhanced tumor which are difficult to be classified due to class imbalance.

**Keywords:** brain tumor; deep learning; 3D UNet; hybrid focus loss function

### 前言

脑肿瘤也称为颅内肿瘤,是指大脑中不可控制的异常细胞生长,它们生长迅速,与周围的正常组织紧密连接,互相浸润,导致边界模糊<sup>[1]</sup>。脑肿瘤病程

发展迅速,可以快速破坏人体的正常功能。目前临床上通常使用脑部核磁共振图像(Magnetic Resonance Imaging, MRI)进行脑肿瘤的诊断以及标注<sup>[2]</sup>。但仅依靠医生手动分割脑肿瘤位置及不同病灶区域,不仅费时费力,且对其诊断经验要求较高,同时具有极大主观性。随着计算机技术的发展,使用计算机和MRI相关技术,辅助诊断脑肿瘤,具有效率高、客观性强等优势<sup>[3]</sup>。随着深度学习在图像分类、目标检测、自然语言处理等领域的成功应用,使用深度学习方法对脑肿瘤进行全自动分割已成为必然趋势。Dong等<sup>[4]</sup>较早地将二维UNet网络用于脑肿瘤分割,但是这种基于二维UNet的模型不能直接

**【收稿日期】**2023-02-24

**【基金项目】**北京市自然科学基金-北京市教育委员会科技计划重点项目(KZ202110011015)

**【作者简介】**田恒屹,硕士,研究方向:图像处理与模式识别,E-mail: thy8562@sina.com

**【通信作者】**肖洪兵,博士,副教授,研究生导师,研究方向:图像处理与模式识别,E-mail: x.hb@163.com

处理三维MRI影像数据,只能分别对每张二维切片进行图像处理。因此,二维UNet模型仅可以提取各切片内部的特征,而忽略了MRI影像中切片之间的层间信息,这在一定程度上会影响模型的分割精度。针对该问题,Beers等<sup>[5]</sup>提出一种三维UNet(3D UNet)网络架构,获得了较好的分割精度。该网络可以直接处理完整的3D MRI影像或其中的三维影像块,使用的三维卷积核在提取影像内各切片信息的基础上,还可以更深层地提取到层间特征。目前,3D UNet因具有良好的分割性能,已成为医学图像分割领域的主流架构,一些先进的深度学习网络均是基于该网络延伸而来<sup>[6-8]</sup>。深度学习端到端的分割方法可以直接输出直观的分割结果,但容易出现数据不平衡的问题。主要原因在于,患者的MRI影像中,肿瘤区域的体积要远小于患者脑部正常组织的体积,一般只占整幅脑影像的1.54%<sup>[9]</sup>,肿瘤内部不同的子区域所占的体积则更小,这会使得在训练阶段,正常组织与背景的负样本在模型中占据主导地位,模型在较少的正样本中难以提取足够有效的特征,使优化路线发生偏移,同时降低模型的优化质量。另外,模型在对输入样本进行分类时,容易出现假阳性与假阴性预测,即输出不平衡问题,进而导致对输入图像的误分割,降低分割精度。

针对上述数据不平衡问题,研究者通常为模型选择合适的损失函数,模型通过反向传播最小化损失函数值,可使其分割性能趋于最优。在图像分割领域,焦点损失函数经常被用于缓解类不平衡问题<sup>[10]</sup>。Abraham等<sup>[11]</sup>提出基于Tversky指数的焦点Tversky损失函数,以解决输出不平衡问题。近年来,混合损失函数逐渐得到广泛应用,其结合多种独立的损失函数,充分利用各损失函数的优点,具有较好的发展潜力。Taghanaki等<sup>[12]</sup>提出结合交叉熵与Dice损失的Combo损失函数。Wang等<sup>[13]</sup>提出联合Dice损失与交叉熵损失的DiceFocal损失函数。这些方法均可以有效解决输出不平衡的问题。然而多数研究使用的损失函数只能解决单一数据的不平衡问题。目前,Yeung等<sup>[14-15]</sup>提出一种新型的基于焦点损失与焦点Tversky损失的混合焦点损失函数,用于二分类的医学图像分割任务中,其研究证实,该函数可以有效缓解类不平衡与输出不平衡的问题。因此,本研究基于3D UNet网络提出一种结合焦点损失与改进的焦点Tversky损失的混合损失函数,改进的焦点Tversky损失函数是在原有焦点Tversky损失函数基础上,增加了对完整肿瘤区域(Whole Tumor, WT)与核心肿瘤区域(Tumor Core, TC)分割任务的约束项,并将混合损失函数应用于多模态多分类的脑肿瘤分

割任务中,与其他损失函数的算法结果对比表明,本研究提出的方法可以显著提升难以分类的TC和增强肿瘤区域(Enhanced Tumor, ET)的分割效果。

## 1 脑肿瘤全自动分割算法

### 1.1 数据预处理

医学图像在采集时,由于成像设备、成像原理以及个体自身差异的影响,原始图像一般会含有亮度不均匀、噪声等现象<sup>[16-17]</sup>。因此,在进行分割之前,脑部肿瘤分割大赛(Brain Tumor Segmentation, BraTS)提供的数据需要进行偏置场校正与标准化等预处理工作,以减少误诊,提高诊断准确性。本文使用N4ITK偏置场校正法<sup>[18]</sup>去除图像的不均匀性,处理前后的脑肿瘤图像实例如图1所示。由于原始数据来自不同机构,由不同扫描仪器获得,因此各组数据的数值范围也会不一致,这就需要使用Z-Score标准化方法,将所有数据的数值统一到一个较小的范围内,同时使图像的数值呈现正态分布,以便于模型在训练过程中的数值计算。本研究对每位患者的4幅模态图像单独做标准化处理,Z-Score标准化公式如式(1)所示:

$$X = \frac{X - \bar{X}}{X_{std}} \quad (1)$$

其中, $X$ 表示患者的一幅模态图像, $\bar{X}$ 为 $X$ 所有体素的平均值, $X_{std}$ 为 $X$ 所有体素的标准差值。




图1 偏置场校正结果

Figure 1 Bias field correction result

### 1.2 3D UNet网络

将经过预处理后的4种模态MRI脑影像作为4个通道,并行输入到深度学习网络中进行特征提取和分割,最终网络将MRI影像中的体素分为水肿(Edema, ED)、坏死与非增强肿瘤(Necrotic and Non-Enhancing Tumor Core, NC & NETC)、ET与背景

(Background, BG)4类,并依据临床需求,以WT、TC与ET分割精度的高低来评估算法性能,其中WT由ED、NC & NETC、ET构成,TC由NC & NETC、ET构成。

本文选取的主干网络为3D UNet网络,提出的网络架构如图2所示,由编码段和解码段组成,编码段提取输入图像的高水平语义特征,解码段依据提取到的特征,重新定位出不同语意区域的位置。编码段由下采样模块和残差卷积模块组成,下采样模块为步长为2的3×3×3卷积。残差卷积模块如图3a所示,包含两个步长为1的3×3×3卷积层和残差连接,第一层卷积核为16,每经过一次下采样,卷积核数量加倍,卷积后采用实例标准化和Leaky Relu激活函数。解码段主要由卷积模块和上采样模块组成,卷积模块如图3b所示,包含两个步长为1的3×3×3的卷积层,卷积后同样采用实例标准化和Leaky Relu激活函数,上采样模块包含一个步长为1的3×3×3反卷积层。解码段使用4次上采样操作,将从编码段提取的低分辨率特征图转换为高分辨率的特征图,实现端到端的分割,同时采用深度监督方式,在网络中加入3个步长为1的1×1×1的卷积层作为分割层,并将各分割层的输出特征插值到相同尺寸后拼接融合,再进行一次步长为1的3×3×3卷积,卷积核数为4,结果

送入softmax层,得到模型的输出概率图。除此之外,3D UNet网络还使用跳跃连接结构,将同一水平来自于解码段与编码段的高低层语义特征相结合,弥补因上采样操作导致图像细节特征丢失的信息损失,可有效提升模型精度<sup>[19]</sup>。

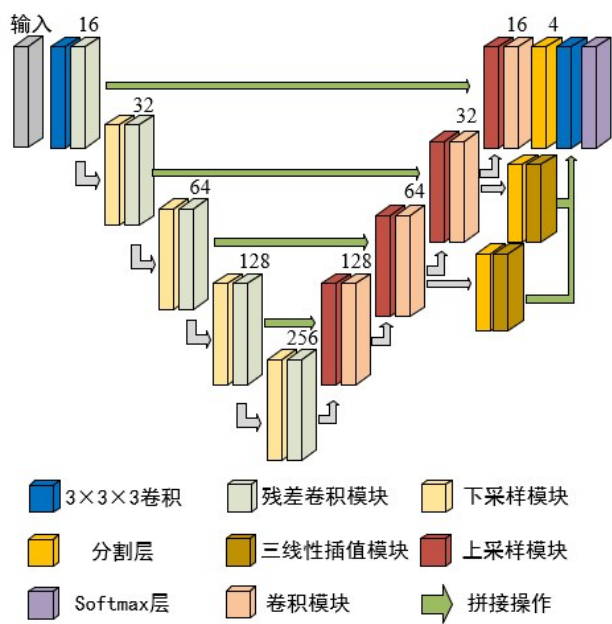


图2 3D UNet网络结构框架图  
Figure 2 Framework of 3D UNet

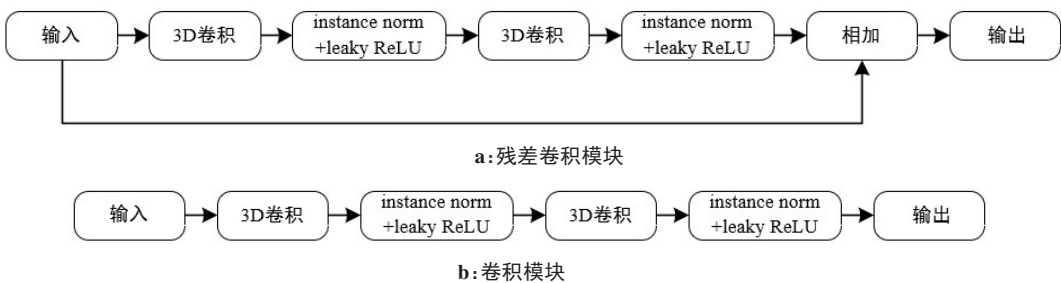


图3 卷积模块结构图  
Figure 3 Structure of convolution module

1.3 混合焦点损失函数

本研究提出一种混合焦点损失函数,用于多模态多分类的脑肿瘤分割任务,该混合焦点损失函数主要由焦点损失与改进的焦点 Tversky 损失两部分函数构成,下面将进行详细阐述。

1.3.1 焦点损失函数 在深度学习网络框架中,传统焦点损失函数由Lu等<sup>[18]</sup>在交叉熵损失函数的基础上进行改进而提出,旨在解决密集目标检测任务的类不平衡问题,其在交叉熵损失的基础上,增加难分类样本与少样本的权重,降低易分类样本与多样本的权重,使模型能够更加专注于肿瘤病灶特征的学习,

同时也可以提高模型对难分类样本的分类精度,针对本文研究的脑肿瘤多分类分割任务,模型使用的焦点损失函数表达式如式(2)所示:

$$L_F = -\frac{1}{N} \mu \sum_{i=1}^N (1 - p_{i,c})^{\tau} \cdot \log(p_{i,c})$$

(2)

其中, $\mu$ 表示正样本的权重,当正样本数量少于负样本时,可以在计算损失函数值时,利用 $\mu$ 增加正样本的比重,从而缓解类不平衡问题。 $\tau$ 称为聚焦参数,且 $\tau \geq 0$ , $(1 - p_{i,c})^{\tau}$ 称为调制系数,主要用于减少易分类样本的权重,使模型在训练时更加专注于难分类的样本, $p_{i,c}$ 表示模型将第*i*个体素预测为该体素的真实



类别  $c$  的概率。  $N$  表示输入到模型的 MRI 数据体素个数, 在本研究中,  $N = 128^3$ ,  $c = 0, 1, 2, 3$ , 分别表示 BG(0)、ED(1)、NC & NETC(2) 与 ET(3)。

**1.3.2 改进的焦点 Tversky 损失函数** 焦点 Tversky 损失函数起源于 Dice 损失函数, 主要用于减少模型的假阳性与假阴性预测。通过设置该损失函数中的权重  $\alpha$  和  $\beta$  值, 可以增加假阳性与假阴性样本在损失值中的比重, 从而使模型能够聚焦学习这些预测错误样本的特征, 提高模型的分割精度。焦点 Tversky 损失函数的表达式如式(3)与式(4)所示:

$$L_{FT} = \sum_{c=0}^C (1 - TI_c)^{\frac{1}{\gamma}} \quad (3)$$

$$TI_c = \frac{\sum_{i=1}^N p_{ic} g_{ic}}{\sum_{i=1}^N p_{ic} g_{ic} + \alpha \sum_{i=1}^N p_{ic} g_{i\bar{c}} + \beta \sum_{i=1}^N p_{i\bar{c}} g_{ic}} \quad (4)$$

其中,  $\gamma$  是一个超参数, 当  $\gamma < 1$  时, 模型可以增加对更难分的区域的关注程度。  $TI_c$  表示类别  $c$  的 Tversky 指数,  $p_{ic}$  表示模型对第  $i$  个体素属于类别  $c$  的预测概率,  $g_{ic}$  表示第  $i$  个体素属于类别  $c$  的真实概率,  $g_{i\bar{c}}$  表示第  $i$  个体素属于非类别  $c$  的真实概率,  $p_{i\bar{c}}$  表示模型对第  $i$  个体素属于非类别  $c$  的预测概率。  $\alpha$  和  $\beta$  作为一组超参数, 分别控制着假阴性和假阳性样本在损失值中的权重, 通过调整  $\alpha$  和  $\beta$ , 可以控制假阳性和假阴性之间的平衡, 缓解输出不平衡问题。

由于在前人研究中  $C=3c = 0, 1, 2, 3$ , 既输出包含 4 种类别的分类结果, 分别为 BG(0)、ED(1)、NC & NETC(2) 与 ET(3), 因此, 损失函数没有对临床所需的 WT、TC 区域进行直接优化, 只能通过对 ED、NC & NETC、ET 这 3 类原始输出结果的优化, 间接影响 WT、TC 区的预测。因此, 本文对焦点 Tversky 损失函数进行改进, 增加对 WT 和 TC 区域的直接监督约束项, 进而进一步增强模型对临床需求的 WT 和 TC 的预测能力, 提出的改进焦点 Tversky 损失函数如式(5)所示:

$$L_{FT+} = \sum_{c=0}^C (1 - TI_c)^{\frac{1}{\gamma}} + (1 - TI_{WT})^{\frac{1}{\gamma}} + (1 - TI_{TC})^{\frac{1}{\gamma}} \quad (5)$$

其中,  $TI_{WT}$  表示 WT 区域的 Tversky 指数,  $TI_{TC}$  表示 TC 区域的 Tversky 指数。

**1.3.3 混合焦点损失函数** 焦点损失函数可以缓解输入数据类不平衡的问题, 而改进的焦点 Tversky 损失函数可以缓解输出数据类不平衡的问题, 同时二者都可以使模型聚焦在难分类样本的学习上。为了使模型在构建过程中, 尽可能避免输入与输出数据不平衡的问题, 本研究提出结合焦点损失与改进的焦点 Tversky 损失, 形成混合焦点损失函数, 使其同时具备两种损失函数的优点。混合损失函数的表达式

如式(6)所示:

$$L = \lambda L_F + (1 - \lambda) L_{FT+} \quad (6)$$

其中,  $\lambda$  为介于  $[0, 1]$  之间的权重系数, 用于调节每一次损失函数计算过程中焦点损失值与改进的焦点 Tversky 损失值的比重。

## 2 结果与分析

为验证提出的算法在脑肿瘤分割中的效果, 设计一系列对比实验, 观察不同算法对实验结果的影响, 并分析原因。本研究的实验环境搭载在一台宝德服务器上, 带有 12 GB 显存的 GPU、750 GB 的硬盘容量、32 GB RAM、Ubuntu16.04LTS 操作系统, 使用的软件平台为 Pycharm、Python3.7 以及相关的 Python 函数库。

### 2.1 模型评价指标

分割算法将从患者多模态 MRI 影像中分割出 WT、TC 和 ET 区域, 其中 WT 包含 TC, TC 包含 ET, 3 种区域呈逐级嵌套的拓扑结构。本文使用 Dice 系数、敏感度和 95% 的豪斯多夫距离评估模型对 3 种区域的分割性能, 其中 Dice 系数为主要的评价指标, 豪斯多夫距离主要用于评估模型对肿瘤边界的分割精度, 敏感度也称为召回率, 可以显示损失函数对分割结果的影响程度。3 种指标的表达式分别如式(7)~式(9)所示:

$$\text{Dice}(P, T) = \frac{|P \cap T|}{(|P| + |T|)/2} \quad (7)$$

$$\text{Sensitivity}(P, T) = \frac{|P \cap T|}{|T|} \quad (8)$$

$$\text{Hausdorff}(X, Y) = \max \left\{ \max_{x \in X} \min_{y \in Y} d(x, y), \max_{y \in Y} \min_{x \in X} d(x, y) \right\} \quad (9)$$

其中,  $P$  表示模型预测出的病灶区域,  $T$  表示真实的病灶区域,  $\cap$  表示逻辑“与”操作,  $x$  表示  $T$  区域表面  $X$  的点,  $y$  表示  $P$  区域表面  $Y$  的点, 函数  $d$  用来计算点  $x$  与  $y$  的距离。

### 2.2 数据集及实验设置

本文选取 BraTS2019 公共训练数据集<sup>[20-22]</sup>对模型进行训练和测试, 数据集包括 335 例脑胶质瘤, 其中 76 例低级胶质瘤和 259 例高级胶质瘤。这些数据是术前 MRI 图像, 包括  $T_1$  加权 ( $T_1$ -Weighted MRI,  $T_1$ )、 $T_1$  对比增强加权 ( $T_1$ -Weighted MRI with Contrast Enhancement,  $T_{1ce}$ )、 $T_2$  加权 ( $T_2$ -Weighted MRI,  $T_2$ ) 和  $T_2$  液体衰减反转恢复 (Fluid-Attenuated Inversion Recovery, FLAIR) 4 个模态图像和 1 张专家标注的肿瘤标签图像, 患者的图像数据如图 4 所示。




图4 某位患者 4 种模态 MRI 图像与医生标注脑肿瘤图像实例

Figure 4 Four modal MRI images and physician-labeled brain tumor image of a patient

实验使用五折交叉验证,将 BraTS2019 数据集按照 4:1 划分为训练集与测试集,输入图像块的尺寸为  $160\times160\times160$  体素,使用 Adam 优化器对网络进行优化,初始学习率为  $1e-04$ ,衰减率为  $1e-05$ ,dropout=0.5,批大小为 2,epoch 个数为 190。

实验的基本流程为:第一步,对 BraTs2019 数据集中的 MRI 影像进行偏置场校正和标准化预处理;第二步,对预处理后的 MRI 影像进行基本的数据增

强,如平移、翻转、旋转、镜像等,每个操作默认的使用概率是 0.3,数据增强的结果如图 5 所示;第三步,使用增强后的数据以及混合焦点损失函数训练优化 3D UNet 模型;第四步,使用测试数据测试模型的性能,评估分割结果。为了对各种算法进行公平比较,所有算法均在最优参数设置下获取实验结果,具体的参数设置如表 1 所示。




图5 数据增强可视化结果图

Figure 5 Visualization of data augmentation result

表 1 不同算法的参数设置

Table 1 Parameters set of different methods

| 损失函数                          | 参数设置  |
|-------------------------------|---|
| 交叉熵损失 <sup>[23]</sup>         | -   |
| Dice 损失 <sup>[8]</sup>        | -   |
| 焦点损失 <sup>[14]</sup>          | $\tau=2, \mu=0.25$  |
| 焦点 Tversky 损失 <sup>[24]</sup> | $\alpha=0.3, \beta=0.7, \gamma=0.75$                                |
| 改进的焦点 Tversky 损失              | $\alpha=0.3, \beta=0.7, \gamma=0.75$                                |
| 混合焦点损失                        | $\lambda=0.5, \tau=2, \mu=0.25, \alpha=0.3, \beta=0.7, \gamma=0.75$ |

2.3 实验结果

提出的混合焦点损失函数中,λ 的设置至关重

要,为了确定最优λ值,进行了多种实验尝试,具体结果如表 2 所示。从表 2 的实验结果可知,λ 值不同,损失函数对模型优化的作用也不同,在输入临床数据对模型进行训练时,不同的λ 参数值会决定模型优化的方向,当λ 为 0.5 时,TC 和 ET 由于样本少导致难以分类的区域,获得了最佳的实验结果,而 WT 的结果只是略微有所下降,总体来说效果最好,因此在后续实验中,设置λ=0.5。

为了验证提出算法的性能,本研究使用 4 种对比算法,包括交叉熵损失、Dice 损失、焦点损失与焦点 Tversky 损失函数,分割结果如图 6 所示,客观评测结果如表 3 所示。通过表 3 的结果可以看出,在脑肿瘤分割模型中,使用不同的损失函数,可以产生不同的分割结果。其

表2 不同λ值的实验对比结果  
Table 2 Results of experiments with different λ

| 参数值   | Dice均值/% |       |       | 敏感度均值/% |       |       | 豪斯多夫距离均值/mm |      |      |
|-------|----------|-------|-------|---------|-------|-------|-------------|------|------|
|       | WT       | TC    | ET    | WT      | TC    | ET    | WT          | TC   | ET   |
| λ=0.1 | 87.36    | 87.58 | 81.56 | 91.58   | 85.41 | 83.49 | 13.46       | 7.89 | 5.53 |
| λ=0.3 | 88.46    | 88.44 | 83.12 | 94.82   | 87.15 | 82.16 | 14.48       | 6.16 | 6.58 |
| λ=0.5 | 89.01    | 88.67 | 83.74 | 90.36   | 86.43 | 84.20 | 14.29       | 5.01 | 3.84 |
| λ=0.7 | 88.12    | 85.64 | 81.79 | 89.19   | 85.17 | 81.29 | 15.32       | 8.32 | 4.18 |
| λ=0.9 | 89.42    | 86.48 | 82.47 | 90.65   | 85.42 | 80.89 | 13.67       | 7.46 | 5.72 |

中,改进的焦点 Tversky 损失在各项指标均优于焦点 Tversky 损失。使用混合焦点损失函数的模型在 TC 与 ET 的分割效果最好,与单独焦点损失函数相比,混合焦点损失函数在 TC 与 ET 区域的 Dice 均值分别提升 3.54% 与 2.84%;与改进的焦点 Tversky 损失函数相比,混合焦点损失函数分别提升 1.63% 与 1.18%。此外,使用混合焦点损失函数的模型对 TC 与 ET 分割的豪斯多夫距离均值均为最小,因此使用混合焦点损失函数进行脑肿瘤分割,有利于提升模型对 TC 与 ET 的分割精度。然而,与焦点损失和改进的焦点 Tversky

损失函数相比,使用混合焦点损失函数的模型在 WT 的 Dice 均值分别下降 0.78% 与 0.34%,这说明混合焦点损失函数对于 WT 的分割不具有优势,原因可能是混合焦点损失函数使模型专注于学习数量较少的难分类的样本,例如 TC 与 ET 的样本,而 WT 的样本相对于 TC 与 ET 较为容易识别。因此,在混合焦点损失值的比重会被降低,使得模型对 WT 的分割能力没有得到明显提升。但总体来说,使用混合焦点损失函数的模型,在脑肿瘤分割任务中,尤其是难以分类的 TC 和 ET 区域,获得了优秀的结果。

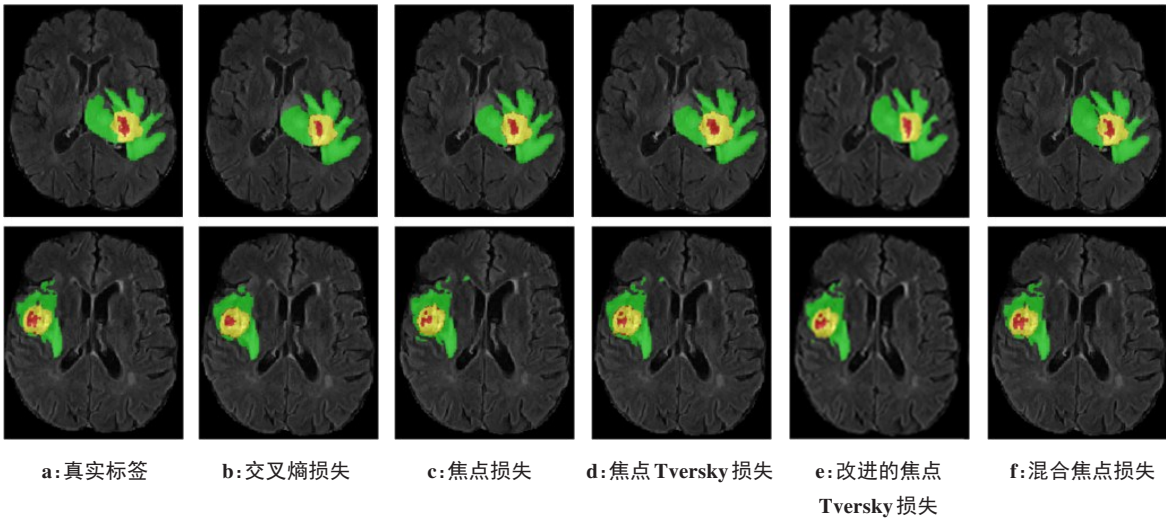


图6 某位患者MRI脑肿瘤分割结果实例  
Figure 6 Brain tumor segmentation results of a patient

ED: 绿色;ET: 黄色;NC & NETC: 红色;WT: 绿色+黄色+红色;TC: 黄色+红色

从图6可以看出,本文提出的混合焦点损失函数,对于肿瘤TC和ET区域分割更为准确。图6b的分割结果显示,原始的交叉熵损失函数会将ET区边缘部分错误地归类于TC区。在图6c与图6d中,焦点损失和焦点 Tversky 损失函数缓解了上述问题,但仍在TC区出现欠分割现象,而本研究提出的改进的焦点 Tversky 损失函数使网络对TC区的分割更加精准。综合比较下,本研究提出的混合焦点损失函数,使分割出的肿瘤区域,尤

其是TC和ET区域,与真实标签图像更加接近。

3 结 论

脑肿瘤分割对于肿瘤的诊断分级和治疗方案规划十分重要,而自动分割技术可以极大缓解手动分割耗时耗力和依赖医生主观认知带来的不利影响<sup>[25]</sup>。文中基于3D UNet,搭建了网络框架,针对在学习模型偏向背景区域,对体积较小的前景区域分割效果不佳的



表3 不同损失函数的实验结果  
Table 3 Experimental results of different loss functions

| 损失函数                          | Dice 均值/% |       |       | 敏感度均值/% |       |       | 豪斯多夫距离均值/mm |       |       |
|-------------------------------|-----------|-------|-------|---------|-------|-------|-------------|-------|-------|
|                               | WT        | TC    | ET    | WT      | TC    | ET    | WT          | TC    | ET    |
| 交叉熵损失 <sup>[23]</sup>         | 83.24     | 76.03 | 72.45 | 83.67   | 82.37 | 76.29 | 25.87       | 30.61 | 21.67 |
| Dice 损失 <sup>[8]</sup>        | 84.57     | 78.34 | 73.52 | 82.54   | 80.41 | 75.28 | 24.39       | 28.64 | 20.17 |
| 焦点损失 <sup>[14]</sup>          | 89.79     | 85.13 | 80.90 | 94.08   | 87.46 | 80.77 | 13.61       | 7.47  | 5.45  |
| 焦点 Tversky 损失 <sup>[24]</sup> | 88.37     | 86.71 | 82.37 | 91.49   | 85.45 | 81.16 | 15.72       | 7.29  | 6.78  |
| 改进的焦点 Tversky 损失              | 89.35     | 87.04 | 82.56 | 93.88   | 86.43 | 82.27 | 13.21       | 6.34  | 4.16  |
| 混合焦点损失                        | 89.01     | 88.67 | 83.74 | 90.36   | 87.62 | 84.20 | 14.29       | 5.01  | 3.84  |

问题,提出混合焦点损失函数,包含焦点损失与改进的焦点 Tversky 损失函数两部分,焦点损失和改进的焦点 Tversky 损失函数可以分别缓解输入与输出数据类不平衡带来的不利影响,并首次应用于多模态 MRI 影像中脑肿瘤分割任务,利用开源的 BraTS2019 数据集,通过对比实验结果发现,改进的焦点 Tversky 损失函数算法的绝大部分结果均优于焦点 Tversky 损失、Dice 损失和焦点损失函数的算法结果,而混合焦点损失函数兼具焦点损失与焦点 Tversky 损失函数的优点,能够缓解输入与输出数据的不平衡问题,显著提升深度学习网络模型对难以区分的 TC 和 ET 区域的分割精度。

【参考文献】

[1] Lapointe S, Perry A, Butowski NA. Primary brain tumours in adults [J]. Lancet, 2018, 392(8): 432-446.

[2] 宫进昌, 赵尚义, 王远军. 基于深度学习的医学图像分割研究进展 [J]. 中国医学物理学杂志, 2019, 36(4): 420-424.

Gong JC, Zhao SY, Wang YJ. Research progress on deep learning-based medical image segmentation[J]. Chinese Journal of Medical Physics, 2019, 36(4): 420-424.

[3] 方新林, 方艳红, 王迪. 基于多模态特征融合的脑瘤图像分割方法 [J]. 中国医学物理学杂志, 2022, 39(6): 682-689.

Fang XL, Fang YH, Wang D. Brain tumor image segmentation method based on multi-modal feature fusion[J]. Chinese Journal of Medical Physics, 2022, 39(6): 682-689.

[4] Dong H, Yang G, Liu F, et al. Automatic brain tumor detection and segmentation using U-Net based fully convolutional networks[C]// International Conference on Medical Image Understanding and Analysis. Cham: Springer, 2017: 506-517.

[5] Beers A, Chang K, Brown J, et al. Sequential 3D U-Nets for biologically-informed brain tumor segmentation [C]//International conference on Computer Vision and Pattern Recognition. Hawaii: IEEE, 2017: 235-242.

[6] Diakogiannis FI, Waldner F, Caccetta P, et al. ResUNet-a: a deep learning framework for semantic segmentation of remotely sensed data [J]. ISPRS J Photogramm Remote Sens, 2020, 162(4): 94-114.

[7] Zhou Z, Siddiquee MM, Tajbakhsh N, et al. Unet++: redesigning skip connections to exploit multiscale features in image segmentation[J]. IEEE Trans Med Imaging, 2019, 39(6): 1856-1867.

[8] Isensee F, Jäger PF, Full PM, et al. nnU-net for brain tumor segmentation [C]//International MICCAI Brainlesion Workshop. Cham: Springer, 2020: 118-132.

[9] Shen H, Zhang J, Zheng W. Efficient symmetry-driven fully convolutional network for multimodal brain tumor segmentation[C] //International Conference on Image Processing. Piscataway: IEEE, 2017: 3864-3868.

[10] McKinley R, Meier R, Wiest R. Ensembles of densely-connected CNNs with label-uncertainty for brain tumor segmentation[C]//International

MICCAI Brainlesion Workshop. Cham: Springer, 2018: 456-465.

[11] Abraham N, Khan NM. A novel focal tversky loss function with improved attention U-Net for lesion segmentation[C]//2019 IEEE 16th International Symposium on Biomedical Imaging. Piscataway: IEEE, 2019: 683-687.

[12] Taghanaki SA, Zheng Y, Zhou SK, et al. Combo loss: handling input and output imbalance in multiorgan segmentation[J]. Comput Med Imaging Graph, 2019, 75(5): 24-33.

[13] Wang GT, Li W, Ourselin S, et al. Automatic brain tumor segmentation using cascaded anisotropic convolutional neural networks [C]// International MICCAI Brainlesion Workshop. Cham: Springer, 2017: 178-190.

[14] Yeung M, Sala E, Schönlieb CB, et al. Focus U-Net: a novel dual attention-gated CNN for polyp segmentation during colonoscopy[J]. Comput Biol Med, 2021, 137(10): 104815.

[15] Yeung M, Sala E, Schönlieb CB, et al. Unified focal loss: generalising dice and cross entropy-based losses to handle class imbalanced medical image segmentation[J]. Comput Med Imaging Graph, 2022, 95(1): 102026.

[16] Zeineldin RA, Karar ME, Coburger J, et al. DeepSeg: deep neural network framework for automatic brain tumor segmentation using magnetic resonance FLAIR images[J]. Int J Comput Assist Radiol Surg, 2020, 15(6): 909-920.

[17] Lin TY, Goyal P, Girshick R, et al. Focal loss for dense object detection [C]//International Conference on Computer Vision. Piscataway: IEEE, 2017: 2980-2988.

[18] Lu JL, Wang ZY, Bier E, et al. Bias field correction in hyperpolarized Xe-129 ventilation MRI using templates derived by RF-depolarization mapping[J]. Magn Reson Med, 2022, 88(2): 802-816.

[19] 付顺兵, 王朝斌, 罗建, 等. 基于改进 U-Net 模型的脑肿瘤 MR 图像分割[J]. 西华师范大学学报(自然科学版), 2021, 42(2): 202-208.

Fu SB, Wang ZB, Luo J, et al. MR image segmentation of brain tumor based on improved U-Net model[J]. Journal of China West Normal University (Natural Science Edition), 2021, 42(2): 202-208.

[20] 刘昊, 王冠华, 章强, 等. 3D 脑肿瘤分割的 Dice 损失函数的优化[J]. 中国医疗设备, 2019, 34(5): 20-23.

Liu H, Wang GH, Zhang Q, et al. Optimization of Dice loss function for 3D brain tumor segmentation[J]. Chinese Medical Equipment, 2019, 34(5): 20-23.

[21] Menze BH, Jakab A, Bauer S, et al. The multimodal brain tumor image segmentation benchmark (BRATS)[J]. IEEE Trans Med Imaging, 2014, 34(10): 1993-2024.

[22] Bakas S, Akbari H, Sotiras A, et al. Advancing the cancer genome atlas glioma MRI collections with expert segmentation labels and radiomic features[J]. Sci Data, 2017, 4(1): 1-13.

[23] Bakas S, Reyes M, Jakab A, et al. Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge[J]. arXiv preprint arXiv: 1811.02629, 2018.

[24] Huang G, Liu Z, Laurens VD, et al. Densely connected convolutional networks [C]// International Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2017: 4700-4708.

[25] Salehi SS, Erdogmus D, Gholipour A. Tversky loss function for image segmentation using 3D fully convolutional DeepNetworks [C]// International conference on Machine Learning in Medical Imaging. Cham: Springer, 2017: 379-387.

(编辑:陈丽霞)